

UNIVERZA V LJUBLJANI
FAKULTETA ZA RAČUNALNIŠTVO IN INFORMATIKO

Matej Senožetnik

Ocenjevanje stanja napolnjenosti baterije inteligentnega avtodoma

DIPLOMSKO DELO

VISOKOŠOLSKI STROKOVNI ŠTUDIJSKI PROGRAM PRVE
STOPNJE RAČUNALNIŠTVO IN INFORMATIKA

MENTOR: izr. prof. dr. Janez Demšar

SOMENTORICA: izr. prof. dr. Dunja Mladenec

Ljubljana 2015

Fakulteta za računalništvo in informatiko izdaja naslednjo nalogo:

Tematika naloge:

Ocenjevanje stanja napolnjenosti baterije je pomemben, a zahteven problem. Ker stanja ni mogoče izmeriti neposredno, saj je odvisno tudi od dejavnikov, kot sta temperatura in starost baterije, uporabljamo ustrezne metode za ocenjevanje stanja napolnjenosti na podlagi količin, ki jih lahko merimo.

V okviru diplomske naloge opišite metode, ki se običajno uporabljajo v ta namen. Nato na podatkih, zbranih pri uporabi (ali simulaciji uporabe) resničnega avtodoma preverite, katera od izbranih metod dosega največjo natančnost.

IZJAVA O AVTORSTVU DIPLOMSKEGA DELA

Spodaj podpisani Matej Senožetnik sem avtor diplomskega dela z naslovom:

Ocenjevanje stanja napolnjenosti baterije inteligentnega avtodoma

S svojim podpisom zagotavljam, da:

- sem diplomsko delo izdelal samostojno pod mentorstvom izr. prof. dr. Janeza Demšarja in somentorstvom izr. prof. dr. Dunje Mladenić,
- so elektronska oblika diplomskega dela, naslov (slov., angl.), povzetek (slov., angl.) ter ključne besede (slov., angl.) identični s tiskano obliko diplomskega dela,
- soglašam z javno objavo elektronske oblike diplomskega dela na svetovnem spletu preko univerzitetnega spletnega arhiva.

V Ljubljani, 21. avgust 2015

Podpis avtorja:

Zahvaljujem se mentorju izr. prof. dr. Janezu Demšarju in somentorici izr. prof. dr. Dunji Mladenić za pomoč pri diplomskem delu. Prav tako bi se rad zahvalil tudi Luki Stoparju, Primožu Škrabi in Luki Bradešku in vsem ostalim kolegom v Laboratoriju za umetno inteligenco, Klemnuregarju z Odseka za komunikacijske sisteme ter Andreju Debenjaku in Mateju Gašperinu z Odseka za sisteme in vodenje. Zahvaljujem se tudi vsem ostalim, ki so mi pomagali in me vzpodbujali tekom izdelave diplomskega dela. Za konec pa bi se posebej zahvalil domačim za vso izkazano podporo v času študija.

Kazalo

Povzetek

Abstract

1	Uvod	1
2	Tipi in lastnosti baterij	3
2.1	Sestava baterije	3
2.2	Tipi baterij	4
2.3	Li-ionska baterija	4
2.4	Sistem za upravljanje Li-ion baterije	6
2.5	Vplivi na karakteristike baterije	7
3	Metode določanja stanja napolnjenosti	9
3.1	Pogosto uporabljena terminologija pri baterijah	9
3.2	Stanje napolnjenosti baterije	11
3.3	Pregled metod	12
4	Uporaba metod in evalvacija	27
4.1	Opis podatkov	27
4.2	Poskusi	30
4.3	Rezultati	33
4.4	Primerjava implementiranih metod	52
5	Zaključek	55

Seznam uporabljenih kratic

kratica	angleško	slovensko
SVM	Support vector machine	Metoda podpornih vektorjev
SOC	State of charge	Stanje napolnjenosti
SOH	State of health	Stanje iztrošenosti
DOD	Depth of discharge	Globina praznjenja
EMF	Electromotive force	Elektromotorna sila
OCV	Open circuit voltage	Napetost odprtih sponk
EKF	Extended Kalman filter	Razširjen Kalmanov filter
BMS	Battery management system	Sistem za upravljanje baterije
MAE	Mean absolute error	Srednja absolutna napaka
MSE	Mean squared error	Srednja kvadratna napaka

Povzetek

Namen diplomskega dela je razviti in uporabiti metodo, ki bo uspešno ocenjevala stanje napolnjenosti Li-ion baterije v inteligentnem avtodomu. Stanje napolnjenosti je pomemben podatek in zato mora biti čim bolj natančno ocenjen. Ne moremo ga izmeriti, zato ga je potrebno oceniti iz meritev in ga lahko razberemo iz podatkov napetosti, toka, temperature in drugih razpoložljivih podatkov.

V teoretičnem delu predstavimo tehnologijo baterij LiFePO_4 . Razvoj in uporaba metod za ocenjevanje stanja napolnjenosti je razdeljena v štiri skupine, in sicer neposredne metode, metode integriranja, adaptivne sisteme in hibridne metode. Opisali smo ključne značilnosti vsake metode.

V praktičnem delu smo najprej pridobili podatke o toku, napetosti in temperaturi med normalnim obratovanjem baterije. Podatke smo zbrali za več ciklov polnjenja in praznjenja. Pri neposredni metodi smo razvili in testirali napetostno meritev in model baterije. Pri metodi integriranja smo uporabili štetje naboja. Pri adaptivnih sistemih smo uporabili linearno regresijo in metodo podpornih vektorjev. Pri hibridnih metodah smo uporabili kombinacijo adaptivnih sistemov in neposrednih metod ter izbrali linearno regresijo z napetostno meritvijo ter metodo podpornih vektorjev v kombinaciji z napetostno meritvijo. Slednja daje najboljše rezultate, zato smo jo dejansko implementirali v avtodomu.

Ključne besede: ocena stanja napolnjenosti, adaptivni sistemi, strojno učenje.

Abstract

The aim of this thesis is to develop an accurate method for estimating state of charge (SOC) estimation of Li-Ion batteries and use it in the real-world setting in an intelligent mobile home. The state of charge can not be measured directly. While it depends on the past electrical current that flew in/out of the battery and the battery temperature, a reasonable estimation can be made based on the current values of the battery voltage, temperature and incoming/outcoming electrical current.

In the theoretical section, we present various battery technologies, and methods that can be used to predict the SOC information. The methods are divided into four categories: direct methods, integration methods, hybrid methods and adaptive systems. We describe the basic characteristics of each groups and of some methods.

In the practical section, we first acquired the historical measurements of the battery current, voltage and temperature under regular operating conditions. We use the data to compare suitable representatives of each groups of methods. We found out that the best performing method was a combination of the linear regression with voltage measurement and support vector machine, so this method was eventually implemented in the mobile home.

Keywords: machine learning, estimation of the state of charge, adaptive systems.

Poglavje 1

Uvod

Stanje napolnjenosti baterije avtodoma je pomemben podatek za uporabnike avtodoma. V diplomskem delu iščemo in raziskujemo metode za izračun stanja napolnjenosti v inteligentnem avtodomu. Na Institutu "Jožef Stefan" smo skupaj s podjetjem Adria Mobil d.o.o. delali na projektu "KAD13-Inteligenca", katerega rezultat je bil konceptni avtodom Sonic A11 (I770 SL), ki je prototip, na katerem se testira uporabnost novih materialov, senzorjev ter umetne inteligence. Ena izmed nalog je tudi razvoj metode za ocenjevanje napolnjenosti baterije LiFePO_4 . Stanja napolnjenosti ne moremo meriti, zato ga je potrebno oceniti iz meritev toka, napetosti, temperature in drugih razpoložljivih podatkov. V avtodomu je uporabljena baterija, ki temelji na tehnologiji polnilnih baterij Li-ion z anodnim materialom LiFePO_4 . Li-ion tehnologija je vedno bolj zanimiva za uporabo v aplikacijah, v katerih se tradicionalno vgrajuje manj zahtevne in bolj preizkušene vrste baterij.

Celice baterije LiFePO_4 so priključene na sistem za upravljanje baterij, ki skrbi za varnost baterije. Li-ion baterije so zelo občutljive na izpraznjenje pod določeno napetostjo celic, kar povzroča degradacijo. Prav tako so občutljive na polnjenje nad določeno napetostjo, kar prav tako povzroča degradacijo in v določenih primerih lahko vodi v termični pobeg ter samovžig. Celice so občutljive tudi na temperaturo.

Avtodom je bil parkiran na parkirišču Instituta "Jožef Stefan", kjer smo

izvedli meritve. Uporabnih podatkov je bilo za 10 ciklov praznjenja in polnjenja, nekaj ciklov je bilo neuporabnih, zato smo jih zavrgli. Podatke je bilo potrebno obdelati za uporabo metod za oceno stanja napolnjenosti baterije. Poznamo več vrst metod, in sicer:

- **neposredne metode**, ki se nanašajo na fizikalne lastnosti baterije;
- **metode integriranja**, ki uporabljajo tok praznjenja ali polnjenja kot vhodni podatek;
- **adaptivni sistemi**, ki si prilagajajo sistem glede na podatke, ki prihajajo vanj in z njimi dobro ocenimo SOC;
- **hibridne metode**, ki so kombinacija neposrednih metod, metod integriranja in adaptivnih sistemov.

V diplomskem delu smo preizkusili iz vsake skupine vsaj eno izmed metod. Implementirali smo najbolj smiselne, glede na podatke, ki jih pridobivamo, in opremo, ki jo imamo na voljo. Izmed neposrednih meritev smo implementirali model baterije in napetostne meritve. Izmed metod integriranja smo implementirali štetje naboja, kar smo uporabili tudi kot referenčno vrednost. Izmed adaptivnih sistemov smo preskušali linearno regresijo in metodo podpornih vektorjev. Kot hibridno metodo smo tidve metodi kombinirali z ocenami s pomočjo direktnih metod.

Cilja diplomskega dela sta razviti metodo, ki bo učinkovito ocenjevala stanje baterije v avtodomu, in primerjava različnih pristopov za izračun SOC-a, kot so neposredne metode, metode integriranja, adaptivni sistemi ter hibridne metode.

Poglavje 2

Tipi in lastnosti baterij

V tem poglavju spoznamo tipe baterij. Predstavljene so kemijske lastnosti LiFePO_4 baterije, redoks reakcija¹, ki poteka med praznjenjem in polnjenjem baterije, ter vplivi na karakteristike baterije.

2.1 Sestava baterije

Baterija je naprava, sestavljena iz ene ali več elektrokemijskih celic, ki omogoča pretvarjanje kemične energije v električno energijo in obratno [15, 18]. Izraz baterija se pogosto uporablja, čeprav se osnovna elektrokemična enota imenuje celica. Baterija je sestavljena iz ene ali več celic, ki so povezane zaporedno, vzporedno ali oboje, odvisno od zasnovanih ciljev glede izhodne napetosti in kapacitete [22]. Celica je sestavljena iz treh glavnih komponent, in sicer iz:

- **anode ali negativne elektrode**, ki med praznjenjem odda elektrone zunanjemu tokokrogu in se oksidira med elektrokemično reakcijo;
- **katode ali pozitivne elektrode**, ki med praznjenjem sprejme elektrone iz zunanjega tokokroga in se reducira med elektrokemično reakcijo;

¹Reakcija, pri kateri se izmenjujejo elektroni, imenujemo reakcija oksidacije in redukcije ali redoks reakcija.

- **elektrolita ali ionskega prevodnika**, ki je medij za prenos ionov, znotraj celice med anodo in katodo. Elektrolit je ponavadi v tekoči obliki, kot je voda ali drugo topilo, ki raztaplja soli, kisline ali alkane. Nekatere baterije uporabljajo trdne elektrolite, ki so ionski prevodniki.

2.2 Tipi baterij

Baterije delimo na primarne in sekundarne [15, 18]. Primarne baterije po izteku življenjske dobe zavržemo, navadno jih ni mogoče ponovno napolniti, imajo visoko energijsko gostoto in so enostavne za uporabo. Sekundarne baterije so tiste, ki jih je mogoče ponovno napolniti. Potrebujemo jih za energijsko potratne naprave in za tiste, kjer menjavanje baterij ni mogoče ali pa je zamudno oz. predrago.

Obstaja več različnih vrst baterij. Med primarnimi baterijami so najpogostejše cink-karbonske, alkalne, živosrebrne in srebrove. Med sekundarnimi baterijami ločimo svinčeve, nikelj-kadmijeve, nikelj-metalhidridne in Li-ionske. V tem delu obravnavamo Li-ionske baterije, ki jih bomo v nadaljevanju podrobneje spoznali.


2.3 Li-ionska baterija

V Li-ionskih baterijah se med polnjenjem in praznjenjem Li-ioni Li^+ premikajo med pozitivno in negativno elektrodo. Na sliki 2.1 je vidna litijeva baterija, ki jo sestavljajo naslednji deli:

- **anoda** je iz bakra, kjer je aktivni material grafit, ki omogoča interkalacijo² Li^+ ionov;
- **katoda** je iz aluminija, kjer je aktivni material spojina LiFePO_4 ;
- **elektrolit** navadno sestavljajo litijeve soli (npr. LiPF_6), raztopljene v organskem topilu (npr. etilen karbonat $(\text{CH}_2\text{O})_2\text{CO}$);



²Interkalacija pomeni vrivanje Li^+ ionov med plasti grafita.

- **separator** je porozna plast, ki zagotavlja razmik med anodo in katodo ter s tem preprečuje kratek električni stik.




Slika 2.1: Prikazana je shema baterije. Vir: Debenjak, Papa in Petrovčič [6], z dovoljenjem.

Reakcija na anodi in katodi litij-ionske baterije:



Splošna reakcija:



Reakcija iz leve na desno stran predstavlja polnjenje baterije [19]. Med polnjenjem baterije se tako Li^+ ioni kot tudi elektroni premikajo iz katode na anodo. Pri tem se na katodi dogaja proces oksidacije. Od molekule LiFePO_4 se odcepijo Li^+ ioni, hkrati pa molekula odda tudi en elektron. Li^+ ioni na anodo potujejo preko elektrolita, elektron pa preko zunanje električne

povezave. Na anodni strani se Li^+ ioni interkalirajo med grafitne plasti. Med praznjenjem se dogaja ravno obraten proces.

Prednosti Li-ionske baterije so:

- visoka energijska gostota, izražena v Wh/kg;
- velik polnilni tok, kar omogoča hitro polnjenje;
- visoka nominalna napetost celice;
- nima spominskega učinka;
- majhen samo-praznilni tok;
- sestavljena je iz okolju neškodljivih materialov.

Slabosti Li-ionske baterije:

- občutljiva je na praznjenje/polnjenje pod ali nad določeno napetostjo;
- ima ozek temperaturni pas delovanja.


2.4 Sistem za upravljanje Li-ion baterije

Li-ion celice so občutljive na izpraznjenje pod določeno napetostjo celic, kar povzroča degradacijo. Občutljive so tudi na polnjenje nad določeno napetostjo, kar prav tako povzroča degradacijo in lahko v določenih primerih vodi v termični pobeg ter samovžig [6]. Običajno je zahtevana nazivna napetost baterije, ki je višja od napetosti posamezne Li-ion celice. Nominalna napetost celice je 3,2 V. V avtodomu je nominalna napetost 12,8 V (minimalna je 11,5 V in maksimalna je 14,6 V). To pomeni, da je bilo potrebno štiri celice vezati serijsko. Takšna sestava se polni in prazni preko katode prve celice in anode zadnje celice. Zaradi občutljive Li-ion tehnologije je potrebno celico prekiniti iz napajanja ali praznjenja, če pade napetost pod kritično mejo. Sistem za upravljanje Li-ion skrbi za varno delovanje celotnega baterijskega

paketa. To doseže s tem, da v več točkah nadzoruje temperaturo sklada celic, spremlja tok vseh vzporednih vej in napetost vsake posamezne Li-ion celice baterijskega paketa. S tem preprečuje nastanek trajnih poškodb, ki so jim izpostavljene Li-ion celice v primeru neustreznih delovnih pogojev. Poleg navedenega sistema skrbi tudi za izravnavanje napolnjenosti celic znotraj posameznih vej serijsko vezanih celic, s čimer omogoča maksimalno izrabo kapacitete baterijskega paketa.

2.5 Vplivi na karakteristike baterije

Na baterijo vplivajo različni dejavniki, kot so nihanje toka, sprememba temperature in njeno staranje. Slika 2.2 prikazuje, da je v času praznjenja baterije njena napetost odvisna od toka in ni podobna idealni krivulji. Manjši je tok, bolj se približa idealni krivulji. To je posledica ohmske polarizacije, tako imenovani IR padec oz. notranje upornosti elektrod, ionske upornosti elektrolita, upornosti anodnih in katodnih spojev ter upornosti




Slika 2.2: Prikaz spreminjanja napetosti.

ostalih aktivnih komponent [15]. Področje delovanja baterije je omejeno s pragoma napetosti (ang. cut-off voltage). Obstajata zgornji in spodnji prag

napetosti. Navadno sistem za upravljanje baterij skrbi za to, da v primeru prekoračitve omenjenih pragov baterijo iz varnostnih razlogov izključi iz sistema. Vseeno je baterija, ki je pri določenem toku dosegla spodnji prag, še vedno uporabna za bremena, ki zahtevajo manjše tokove.

Življenjska doba je odvisna od več dejavnikov, kot sta spremenljiv tok in temperatura, ki je najbolj priporočljiva med 20°C in 40°C . Pri visokih temperaturah se poveča hitrost kemijskih procesov. Pri višjih temperaturah je baterija bolj podvržena samoizpraznitvi, pri nižjih temperaturah pa se poveča notranja upornost baterije, ki posledično vodi v večji IR padec. Na življenjsko dobo baterije vpliva tudi praznjenje. Če jo nekaj časa konstantno praznimo, bo življenjska doba krajša, kot če delamo premore med praznjenji. Omenimo še lahko, da je učinkovitost baterije odvisna tudi od njene oblike. Baterije, ki se uporabljajo za majhne obremenitve, imajo dolgo življenjsko dobo. Pri tem uporabljajo veliko količino aktivnega materiala in imajo manjšo površino elektrod, na katerih poteka elektrokemijska reakcija. Za baterije, ki imajo višje obremenitve, je pomembno, da imajo čim večjo površino elektrod, ker pri tem zmanjšajo IR padec. Oblika je pomembna tudi zaradi oddajanja toplote, ki se pri reakciji sprošča, saj ne smemo dovoliti, da se toplota akumulira v notranjosti baterije, kar odpravimo z večjim razmerjem površine in prostornine. Pomembna je povezava med temperaturo in kapaciteto baterije. Pri višjih temperaturah se kapaciteta poveča in obratno, pri nižjih temperaturah se kapaciteta zmanjša, kar prikazuje slika 2.3.



Slika 2.3: Povezava kapacitete in temperature.

Poglavje 3

Metode določanja stanja napolnjenosti

V tem poglavju so predstavljene pogosta terminologija, ki se uporablja pri baterijah, pojem stanje napolnjenosti in metode za napovedovanje stanja baterije.

3.1 Pogosto uporabljena terminologija pri baterijah

Za boljše razumevanje predstavljenih metod bomo najprej predstavili izraze, ki se uporabljajo pri ocenjevanju SOC in industriji baterij.

- **C stopnja** je definirana kot večkratnik kapacitete baterije in označuje kolikokrat bi lahko baterijo napolnili v eni uri, če bi jo polnili pri toku C stopnje. Večkratniki, ki so manjši ali večji od C stopnje, se uporabljajo za izražanje večjih ali manjših tokov. Na primer, 1 C stopnja je 50 A v primeru 50 Ah baterije, medtem ko sta $C/2$ in 2 C stopnji enaki 25 A in 100 A.
- **Kapaciteta** je količina shranjenega naboja v bateriji in je navadno izražena v amper urah (Ah).

- **Maksimalna kapaciteta** je maksimalna količina naboja, ki je lahko odvzet iz baterije pod definiranimi praznilnimi pogoji [22].
- **Življenjski cikel** je število ciklov polnjenja in praznjenja, kjer bomo lahko baterijo napolnili nad določeno kapaciteto [1]. Ponavadi je to 80% nominalne kapacitete.
- **Prag napetosti** je najnižja oz. najvišja operativna napetost. Celica tudi pod oz. nad njo deluje, vendar se kviri. Ponavadi jo imenujejo tudi začetna/končna napetost.
- **Samopraznjenje** je izguba naboja, ko akumulator ni v uporabi [19]. Mehanizem samopraznjenja je lokalni redoks proces. Odvisen je od temperature, saj pri nižjih temperaturah zmanjšamo stopnjo samopraznjenja.
- **Stanje iztrošenosti** je podatek, ki odraža splošno stanje baterije v primerjavi z novo [16].
- **Globina izpraznjenosti** je nasprotje SOC-a, ko eden naraste, drugi pade in obratno. Ker ima lahko baterija večjo kapaciteto od nazivne, je mogoče, da je DOD večji od 100%, kar pri SOC ni mogoče.
- **Preostali čas delovanja** je predviden čas delovanja baterije pod določenimi pogoji praznjenja [22].

Predstavljenih je veliko definicij, ki imajo za določene osebe določen pomen (uporabniki, elektrotehniki in ostali). Vsi pojmi niso enako pogosto zastopani in vsak ima svojo prednost ali slabost. Za uporabnika sta najpomembnejša pojma SOC in preostali čas delovanja. Pri tem pa ni podane informacije, kakšno je stanje iztrošenosti baterije. Tudi, če je baterija že skoraj neuporabna, SOC še vedno prikaže razpon med 0 in 100%. S kombinacijo pojmov SOC in preostali čas delovanja lahko delno sklepamo, v kakšnem stanju je baterija. DOD predstavlja obratno vrednost SOC-a, vendar ni preveč pogosto uporabljen. Posebnost DOD-a je v tem, da se meri med 0 in 100%

ali več. Samopraznjenje je povezano s kapaciteto, s SOC-om in preostalim časom delovanja. Če je SOC definiran z metodami, ki niso zmožne zaznati samopraznjenja (na primer štetje naboja), ga ne moremo zaznati.

3.2 Stanje napolnjenosti baterije

Obstaja več definicij stanja napolnjenosti. Po splošno uveljavljeni definiciji je SOC definiran kot odstotek trenutnega naboja v primerjavi z maksimalno kapaciteto baterije [25]. Predstavljen je bil za namen interakcije človek-računalnik in notranji nadzor sistema vozil [22]. Izražen je v odstotkih (100% ali 1,0 = polno in 0% ali 0,0 = prazno). Izračunamo ga po enačbi 3.1, in predstavlja razmerje med trenutno količino shranjenega naboja ter maksimalno kapaciteto baterije.

$$SOC(\%) = \frac{Q_{trenutna}}{Q_{maksimalna}} \quad (3.1)$$

- $Q_{maksimalna}$: maksimalna kapaciteta baterije
- $Q_{trenutna}$: trenutna količina shranjenega naboja baterije

3.3 Pregled metod


V tabeli 3.1 so predstavljene nekatere izmed metod, ki jih srečamo v praksi za ocenjevanje vrednosti SOC-a. Najdemo prednosti in slabosti metod, ki bodo v nadaljevanju predstavljene. Metode za oceno stanja smo razdelili na neposredne metode, metode integriranja, adaptivni sistemi in hibridne metode.

Vrste metod	Tehnika	Vrste baterij	Prednosti	Slabosti
<i>Neposredne meritve</i>	Test praznjenja	Uporablja se na začetku za določanje zmogljivosti	Preprost in točen, neodvisen od SOH-a	Meritev ob odklopljenem sistemu
	Impedančna spektroskopija	Vsi baterijski sistemi	Poda informacijo o SOH-u in kvaliteti	Občutljiva na temperaturo
	OCV	Svinčena, litij, Zn Br	Meritev lahko poteka med delovanjem sistema, poceni	Potrebuje daljši čas za počitek (Tok=0)
	EMF	Svinčena, litij	Meritev lahko poteka med delovanjem sistema, poceni	Potrebuje daljši čas za počitek (Tok=0)
	Notranja upornost	Svinčena, NiCd	Poda informacijo o SOH-u, možnost sprotne meritve	Velika natančnost, toda za kratek čas
<i>Metode integriranja</i>	Štetje naboja	Vse baterije	Točen le, če je dovolj kalibracijskih točk, natančnost meritve	Potrebuje kalibracijske točke, veliko pomanjkljivosti
<i>Adaptivni sistemi</i>	Linearni model	Vse baterije	Meritev lahko poteka med delovanjem sistema, preprosta	Potrebuje referenčne podatke za nastavljanje parametrov
	Umetne nevronske mreže	Vse baterije	Meritev lahko poteka med delovanjem sistema	Potrebuje učne podatke, draga za implementacijo
	Mehka logika	Vse baterije	Meritev lahko poteka med delovanjem sistema	Potrebno je veliko pomnilnika v realnih aplikacijah
	Kalmanov filter	Vse baterije	Meritev lahko poteka med delovanjem sistema, dinamična	Težka implementacija algoritma za filtriranje, ki vsebuje vse vplivne faktorje
<i>Hibridne metode</i>	OCV s Kalmanovim filtrom	Vse baterije	Meritev lahko poteka med delovanjem sistema	Težka implementacija algoritma za filtriranje, ki vsebuje vse vplivne faktorje

Tabela 3.1: Pregled metod za določanje SOC [12, 21, 22, 24].

3.3.1 Neposredne meritve

Neposredne metode merjenja se zanašajo na fizikalne lastnosti baterije, kot so napetost, tok, temperatura in impedanca [7]. Obstaja več metod, ki jih bomo spoznali v nadaljevanju.




Slika 3.1: Osnovni princip računanja vrednosti SOC-a, ki temelji na neposrednih meritvah. Prirejeno po Pop [22].

Napetostne meritve

Med praznjenjem napetost baterije pada in njen nivo se v relaciji s preostalim nabojem spreminja s temperaturo in tokom praznjenja [22]. Slika 3.2 prikazuje napetostno krivuljo Li-ionske baterije med praznjenjem pri različnih tokovih. Pomembna je zveza med napetostjo in kapaciteto v času praznjenja.

Meritev napetosti je razširjena metoda, vendar ni dovolj natančna, da bi jo v praksi samostojno uporabljali. Določitev preostanka naboja baterije samo na podlagi napetosti je računsko manj zahtevna kot štetje naboja, vendar je lahko zavajajoča [2].


Napaka v oceni SOC-a, ki temelji na meritvah napetosti, je lahko popravljena, če je odvisnost med napetostjo baterije, temperaturo in praznjenjem znana. Ko te krivulje vključimo v proces, to postane bolj zapleteno in dražje kot pristop štetja naboja. Metodo smo razvili in preizkusili in je predstavljena v poglavju 4.3.2.



Slika 3.2: Krivulje napetosti Li-ionske baterije pri različnih tokovih praznjenja. Prirejeno po Pop [22].

Meritve impedance

Pri merjenju elektrokemijske impedance se baterijo vzbuja z izmeničnim tokovnim ali napetostnim signalom majhne amplitude [22]. Vzbujaalni signali so lahko sinusne oblike ali poljubni frekvenčno bogati signali. Med tokovnim vzbujanjem baterije se baterija odzove z napetostnim odzivom, ki je neposredno odvisen od elektrokemijske impedance baterije. Med vzbujanjem baterije je potrebno signala toka in napetosti vzorčiti ter ju nato z ustreznimi metodami obdelave signalov obdelati in iz njih pridobiti impedančno karakteristiko. Slika 3.3 prikazuje primer impedančne krivulje za Li-ion baterijo pri različnih stanjih napolnjenosti baterije. Metoda se uporablja za ugotavljanje SOC-a pri Li-ion in SOH-a pri nikelj-kadmijevi ter svinčeni bateriji [21]. Na impedančno krivuljo močno vpliva tudi temperatura.



Slika 3.3: Primer izmerjene impedančne krivulje. Vir: Debenjak, Papa in Petrovčič [6] z dovoljenjem.

Notranja upornost

Trenutno notranjo upornost baterije dobimo tako, da spremembo napetosti delimo s spremembo toka v kratkem časovnem intervalu [21]. Enačba 3.2 opisuje postopek, s katerim izračunamo notranjo upornost. V_1 je napetost pred spremembo, V_2 pa po spremembi. Enako velja za tokova I_1 in I_2 .

$$R_n = \frac{V_2 - V_1}{I_2 - I_1} \quad (3.2)$$

Pri Li-ion baterijah je notranja upornost tipično majhna. Upornost baterije je najmanjša v vmesnem področju napolnjenosti, medtem ko se s približevanjem popolne napolnjenosti oziroma izpraznjenosti izrazito povečuje. Vrednost upornosti je tudi močno odvisna od dolžine izbranega intervala, v katerem izvajamo meritev. Če so intervali predolgi, se poleg notranje upornosti izmeri tudi prispevek ostalih elektrokemičnih reakcij, ki potekajo v bateriji. Za ocenjevanje stanja napolnjenosti sta pomembni tako absolutna

meritev notranje upornosti kot tudi hitrost njenega spreminjanja. Metoda se uporablja tudi za določanje SOH-a.

Test praznjenja

Test praznjenja proizvajalci uporabljajo z namenom, da določijo maksimalno kapaciteto baterije. Ko je baterija polna, jo začnemo prazniti pod konstantnim tokom I . Izmerimo čas t , v katerem se baterija popolnoma izprazni. Nato po enačbi 3.3 dobimo kapaciteto.

$$Q = I * t \tag{3.3}$$

3.3.2 Metode integriranja

Metode integriranja kot vhodni podatek uporabljajo tok praznjenja ali polnjenja.

Štetje naboja

Najbolj preprost način za oceno stanja napolnjenosti baterije je metoda štetja naboja. Temelji na meritvi toka in integracije le-tega po času. Vrednost SOC izračunamo po formuli 3.4, ki je definirana [12]:

$$SOC = \frac{Q_{trenutna}}{Q_{maksimalna}} = SOC_0 + \frac{\int_{t_{SOC0}}^{t_{SOCend}} Idt}{Q_{maksimalna}} \quad (3.4)$$

- $Q_{maksimalna}$: maksimalna kapaciteta baterije
- $Q_{trenutna}$: trenutna količina shranjenega naboja baterije
- SOC_0 : začetna točka

Učinkovitost metode štetja naboja je odvisna od kvalitete senzorja za merjenje toka, temperature baterije in samopraznjenja. Spodaj navedeni učinki lahko vplivajo na natančnost izračuna SOC-a [22].

- **Učinkovitost praznjenja** je odvisna predvsem od SOC-a, temperature in toka. Do določene meje jo lahko praznimo z visokim tokom; ko to mejo dosežemo, jo lahko praznimo le z nižjim. Posledica nižjih temperatur, višjih tokov in staranja baterije vplivajo na zmanjšanje kapacitete baterije.
- **Samopraznjenje**: če baterija nekaj časa ni v uporabi, bo izgubljala naboj. Na izgubo vpliva temperatura. Štetje naboja ne more zaznati izgubljene kapacitete. Zanimivo je dejstvo, da se na mesec izgubi med 6 in 9% kapacitete [19].
- **Izguba kapacitete**: kapaciteta baterije začne padati z uporabo in se zmanjšuje s številom ciklov. Odvisna je od več faktorjev, na primer prekomerno polnjenje ali praznjenje.

- **Meritve senzorjev** toka vplivajo na natančnost izračuna SOC-a.

Problem je nepredvidljivost obnašanja tako baterije kot uporabnika, kar vpliva na natančnost SOC-a. Zato mora biti uporabljen prilagodljiv sistem, ki je zasnovan na neposredni meritvi.

Metodo smo implementirali in opisali v poglavju 4.3.1.

Spremenjen Coulombov števec

Wen Yeau Chang je v članku [7] uporabil kvadratno zvezo, ki omogoča popravljanje toka baterije. Popravljeni tok je predstavljen z enačbo:

$$I_c(t) = k_2 I(t)^2 + k_1 I(t) + k_0 \quad (3.5)$$

kjer je $I_c(t)$ popravljeni tok, $I(t)$ pa izmerjeni tok baterije. Konstante k_0, k_1, k_2 je potrebno predhodno oceniti iz eksperimentalnih podatkov. Avtor študije trdi, da je v primerjavi z osnovno metodo na ta način mogoče doseči boljše rezultate ocenjevanja napolnjenosti baterije.

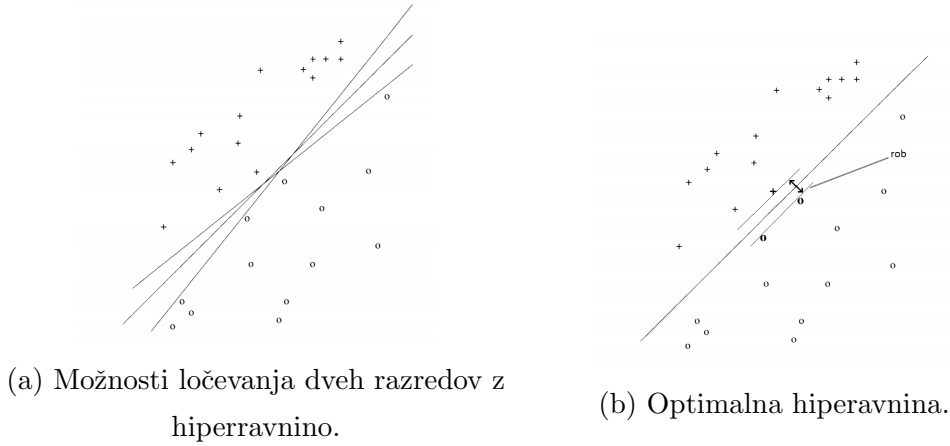
3.3.3 Adaptivni sistemi

Adaptivni sistemi so prilagodljivi sistemi, kot na primer sistemi z mehko logiko, linearno regresijo, metodo podpornih vektorjev, umetno nevronske mrežo in sistemi s Kalmanovim filtrom. Združijo lahko posredne in neposredne meritve; na ta način lahko avtomatsko prilagajajo sistem, glede na vhodne podatke, obenem pa pridobimo dobro oceno SOC-a [26].

Metoda podpornih vektorjev


Metoda podpornih vektorjev je metoda strojnega učenja, razvita iz statistične teorije. Izboljša pomanjkljivosti umetne nevronske mrežne strukture, odvisne od izkušenj poznavalca in bolje reši veliko število problemov [12]. Primarno je SVM binarna klasifikacijska metoda, lahko pa se uporablja tudi za ločevanje več razredov, tudi za regresijske probleme, kot je SOC. Primerna je za učenje na velikih množicah primerov, z velikim številom manj pomembnih atributov. Slaba stran metode je, da je interpretacija naučenega težavna.

Osnovna ideja metode je poiskati hiperravnino, ki ločuje predmete iz različnih razredov, kar je razvidno na sliki 3.4a [14]. Optimalna hiperravnina je enako oddaljena od obeh razredov. Naučeni primeri zraven optimalne ravnine se imenujejo podporni vektorji. Razdalja med hiperravnino in podpornimi vektorji se imenuje rob; metoda temelji na optimizacijskem postopku, ki išče hiperravnino s čim širšim robom (Slika 3.4b).



Slika 3.4: Določanje hiperravnine. Vir: Kononenko [14]

Trenutno je aktualna različica z mehkim robom ki dopušča, da se nekateri učni primeri nahajajo na napačni strani ravnine in s tem se poveča robustnost. Pri linearno neločljivih podatkih lahko preslikamo vhodne podatke v višje dimenzionalni prostor, kjer lahko najdemo boljšo hiperravnino, ki loči učne primere. Pri tej operaciji se pojavi težava: transformiranje vektorjev v prostor z višjo dimenzijo, bi bila računsko zelo zahtevna operacija.



Slika 3.5: Preslikava neločljive funkcije v ločljivo funkcijo. Vir: Wikipedia [4].

Zato transformacijo in inverzno transformacijo opravimo, ne da bi jo dejansko računsko izvedli z uporabo jader [9]. Tudi tukaj zadošča uporaba le

enega dela učnih vektorjev (podporni vektorji) za popolni opis meje med razredi.

Kononenko v knjigi [13] opiše tudi regresijski SVM "Metodo SVM lahko prilagodimo za reševanje regresijskih problemov tako, da definiramo rob ob regresijski hiperravnini, znotraj katerega menimo, da je odvisna spremenljivka za vse primere eksaktno napovedana, zunaj njega pa so podporni vektorji, ki določajo potek hiperravnine. Rob ob hiperravnini želimo minimizirati, hkrati pa želimo minimizirati tudi napako na učnih primerih. Podobno kot pri klasifikacijskih SVM je tudi v regresiji potrebno optimizirati kriterijsko funkcijo, ki upošteva napake napovedi regresijske spremenljivke na učnih primerih ter kompleksnost funkcije (velikosti uteži implicitno generiranih atributov)".

Hansen in Wang [10] sta uporabila SVM za oceno SOC. SVM omogoča nekaznovanje določenih napak, kar povečuje njegovo robustnost ϵ . Njegova točnost se približa EKF, če pravilno optimiziramo parametre, njegova poraba procesorske moči se lahko enači z štetjem naboja.

Tudi v našem primeru je bil uporabljen SVM za reševanje problema. Kako smo SVM prilagodili za oceno SOC-a, je opisano v poglavju 4.3.3.

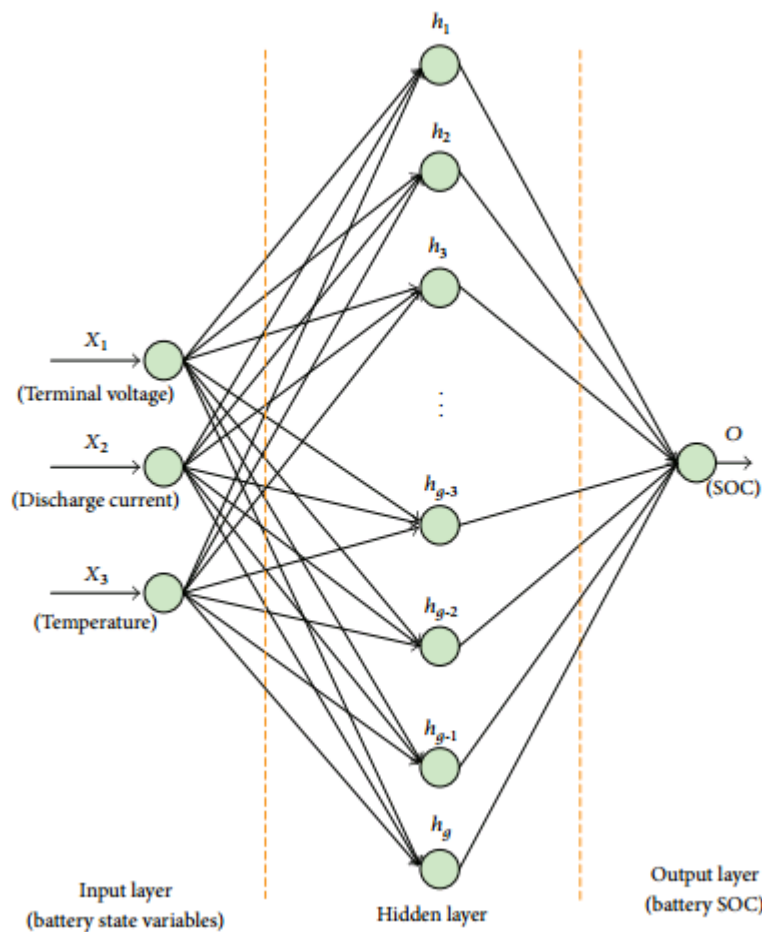
Umetna nevronska mreža

Umetna nevronska mreža je matematični model, ki v nekaterih pogledih deluje po vzoru človeških možganov. Nevroni so osnovni element nevronske mreže [11]. Trdimo lahko, da je nevron element, ki sprejme nekaj podatkov, jih procesira in vrne kot rezultat. Ta rezultat je lahko vhodni podatek za naslednje nevrone. Nevroni se povezujejo v mreže. Najenostavnejše nevronske mreže imajo običajno le en nivo, lahko pa imajo tudi več nivojev.

Baterija je močno nelinearni sistem, zato je težko zgraditi točen matematični model procesa polnjenja in praznjenja. Nevronska mreža ima zmožnost učenja in prilagodljivo strukturo, zato lahko dobro oceni SOC.

Chang je v članku [7] za oceno SOC uporabil vzvratno propagirajočo nevronska mrežo. Sestavljajo jo tri plasti, in sicer vhodna, skrita ter izhodna

plast. V vhodni plasti je uporabil tri nevrone, ki vključujejo napetost, tok in temperaturo. Skrita plast vsebuje g nevronov. Število nevronov v skriti plasti ni točno definirano. Ponavadi uporabimo $g = 6, 10 \dots$. Izhodna plast vsebuje samo en nevron, kar je razvidno na sliki 3.6.




Slika 3.6: Prikazana je struktura nevronske mreže. Vir: Chang [7].

Mehka logika

Mehke množice so nadgradnja običajnih ostrih množic. Osnovna ideja mehkih sistemov je, da so vrednosti v intervalu $[0, 1]$. Podatki so lahko organizirani v ostre ali mehke množice [23] in so lahko okarakterizirani na dva načina, in sicer kot jasni in nejasni. Jasni podatki so podatki, ki so jasno določeni,

na primer temperatura 25°C . Na drugi strani pa so nejasni podatki nejasno določeni, na primer temperatura je "topla". Besedni določevalec lahko zajame velik razpon temperatur in stopnja, do katere "jasni" podatki padejo v "nejasen" set "toplo", je določena s količino, ki jo označujemo s pripadnostno funkcijo v skupino "toplo".



Slika 3.7: Pripadnostna funkcija za temperaturo. Prirejeno po Salkind [23].

Na sliki 3.7 je prikazana stopnja članstva različnih temperatur v nejasnih podzbirih: mrzlo, toplo in vroče. Premislimo razpon možnih vrednosti temperatur kot zbir vseh temperatur. Podzbir temperatur je lahko definiran kot zbir vseh temperatur med 20 in 30°C . Ta podzbir bomo imenovali zbir "vroča" temperatura. Jasno je, da če namerimo 25°C , to temperaturo označimo kot "vročo" temperaturo. Ko namerimo $22,5^{\circ}\text{C}$, pa ta temperatura ni več tako jasno očitna.

Salkind je s sodelavci v članku [23] opisal uporabo mehke logike za oceno stanja SOC-a.

Linearna regresija

Linearna regresija se uporablja takrat, ko je rezultat ali odvisna spremenljivka numerična [27, 28]. Podatke lahko predstavimo v matrični obliki, ki jih lahko definiramo:

- n predstavlja število vrstic oz. primerov;
- p predstavlja število atributov;
- Y predstavlja razred, ki ga poskušamo napovedati in je v velikosti $n \times 1$;
- X predstavljajo attribute, s katerimi lahko definiramo razred, in je velikosti $n \times (p + 1)$;
- β predstavljajo uteži in so velikosti $(p + 1) \times 1$.

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} \quad X = \begin{bmatrix} 1 & x_{11} & \cdots & x_{1p} \\ 1 & x_{21} & \cdots & x_{2p} \\ \vdots & \vdots & \vdots & \vdots \\ 1 & x_{n1} & \cdots & x_{np} \end{bmatrix} \quad \beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_p \end{bmatrix} \quad (3.6)$$

Razred lahko izrazimo, kot je razvidno iz enačbe 3.7. Uteži so izračunane iz učnih podatkov.

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \cdots + \beta_p X_{ip} \quad (3.7)$$

Za ocenjevanje parametrov sistemov β je na voljo veliko število metod, ki se razlikujejo po računski zahtevnosti algoritmov, robustnosti [3]. Najpomembnejša je metoda najmanjših kvadratov. Slednja določi ocene parametrov, ki minimizirajo vsoto ostankov (SSE), kar je prikazano v enačbi 3.8

$$SSE = \sum_{i=1}^n (y_i - \beta x_i)^2 \quad (3.8)$$

Splošno za regresijski model z več neodvisnimi spremenljivkami pa velja, da oceno najmanjših kvadratov dobimo iz p enačb, kar je prikazano na 3.9.

$$\hat{\beta} = (X'X)^{-1}X'Y \quad (3.9)$$

Uteži so izračunljive, če obstaja inverz matrike $(X'X)^{-1}$. Linearna regresija je učinkovita, enostavna metoda za numerično napoved in je široko uporabljena v statističnih aplikacijah že desetletja. Seveda imajo linearni modeli slabosti, če imajo podatki nelinearno odvisnost. Linearni modeli služijo tudi kot gradniki kompleksnejših metod učenja.

3.3.4 Hibridne metode

Hibridne metode so kombinacija že opisanih metod. Z njimi poskušamo izničiti ali vsaj omiliti slabosti posamezne metode. Opisana je metoda razširjenega Kalmanovega filtra z metodo napetosti odprtih sponk. Ideja in implementacija SVM-ja z napetostno meritvijo je opisana v poglavju 4.3.4.

Razširjen Kalmanov filter z metodo napetosti odprtih sponk

Razširjen Kalmanov filter spada v skupino adaptivnih sistemov. To je algoritem za ocenjevanje stanj procesa iz meritev. Navadni Kalmanov filter je uporabljen za ocenjevanje linearnih procesov in deluje v dveh stopnjah.

V prvem delu opravimo časovno posodobitev, v katerem trenutno stanje in kovarianco napake procesa projiciramo najprej po času, da dobimo a priori oceno prihodnjega stanja [20]. Ker v tem delu preko enačb napovedujemo stanje sistema za določen trenutek v prihodnosti, jih lahko poimenujemo prediktorske enačbe. Drugi del imenujemo merilno posodabljanje, kjer s pomočjo meritev, ki so nam na voljo, popravimo našo napoved iz prvega dela in tako dobimo a posteriori oceno stanja ter kovarianco napake procesa. Preko enačb v tem delu popravljamo naše napovedi iz prvega dela in jih lahko imenujemo korektorske enačbe. Napovedovanje stanja napolnjenosti je izrazito nelinearno, zato uporabimo razširjen Kalmanov filter. Najbolj enostaven je filter z enim stanjem za implementacijo, vendar ne dosega velike natančnosti. Točnost se povečuje s številom stanj, obenem se večata tudi njegova zapletenost in potreba po procesorski moči. Pri metodi napetosti odprtih sponk smo izpostavili slabost, da baterija potrebuje počitek.

Lee [17] je predstavil metodo odprtih sponk z razširjenim Kalmanovim filtrom. Ta metoda naj bi bila optimalno prilagodljiv algoritem na podlagi rekurzije. Za izboljšanje učinkovitosti morajo biti izbrani pravi parametri. Vedeti je potrebno, da parametri, kot so upornost, kapacitivnost in OCV-SOC niso konstantni pri spremembah SOC-a, temperature ter staranja. Razmerje med OCV-SOC se razlikuje, zato pride do napak v oceni. Predlaga se modificiranje razmerja, ki bo neodvisno od pogojev baterije.

Poglavje 4

Uporaba metod in evalvacija

Najprej opišemo podatke, kje in kako smo jih pridobili in nato obdelali. Predstavili smo mere za uspešnost učenja, s katerimi smo izmerili napake pri ocenjevanju SOC-a. V poglavju 4.3 so opisane implementirane metode.

4.1 Opis podatkov

Podatke smo pridobili v realnem okolju, in sicer z meritvami v prototipnem avtodomu Sonic A11 (I770 SL), na katerem se testira uporabnost novih materialov, senzorjev ter umetne inteligence. Poleg uporabe novih materialov pri izdelavi karoserije je avtodom opremljen s preko 60 senzorji in aktuatorji ter z računalniškim sistemom. Obdelani, kot tudi izvorni senzorski podatki, se pošiljajo za avtodom prilagojenemu ekspertnemu sistemu, ki se nato samostojno ali s pomočjo uporabnika odloči za različne odzive ter akcije avtodoma. Dogajanje v avtodomu je prav tako mogoče spremljati in upravljati na daljavo preko mobilne aplikacije, na kateri lahko spremljamo dogajanje ter vplive na obnašanje nekaterih komponent avtodoma (trenutno prižgane luči, peč, projektirno platno, vodna črpalka, CO₂ senzor, temperaturni senzor, svetlobni senzorji in podatki o vlagi). V avtodomu je vgrajena baterija z LiFePo₄ katodnim materialom. Izdelana je bila namensko in je sestavljena iz štirih elektrokemičnih celic, ki so vezane serijsko.

Prva faza ocene SOC-a je zajemanje podatkov. Slednje smo zajeli v avtodomu, ki je bil za potrebe merjenja in pridobivanja podatkov večino časa parkiran na parkirišču Instituta “Jožef Stefan”.


Za cilj smo si zastavili pridobiti čim bolj realne podatke. V ta namen smo napisali skripto, s pomočjo katere so se naključno prižigale luči, vklopilo pre-zračevanje in prižgal hladilnik. Čas naključnega preklapljanja uporabnikov je bil izbran med eno in šestimi urami. Najprej je bilo potrebno napolniti baterijo. Po začetnem polnjenju baterije smo jo spraznili s preklapljanjem uporabnikov, za kar je poskrbela skripta. Cikli praznjenja in polnjenja so različno dolgi ter se gibljejo med 39 in 90 ur. Uporabnih podatkov je bilo zbranih za 10 ciklov, ki smo jih uporabili za nadaljnjo obdelavo. Nekaj ciklov je bilo iz različnih razlogov neuporabnih. Dobri učni podatki morajo zagotavljati določene kriterije, in sicer:

- učni podatki pokrivajo vrednosti pri praznjenju med 10,7 in 13,22 V, ter tok med 0 in 13 A, pri polnjenju pa med 10,6 in 14,2 V, ter tok med 0 in 22 A. Pridobljen je še podatek o temperaturi in informacija o priklopu na zunanji vir električne energije;
- podatki so bili izmerjeni v različnih temperaturnih območjih med decembrom 2014 in julijem 2015.

Podatke o toku, napetosti, temperaturi in informaciji o priklopu na zunanji vir električne energije smo pridobivali v različnih časovnih intervalih, ki so se shranjevali v bazo podatkov na strežniku. Vse zbrane podatke je bilo potrebno pred nadaljnjo obdelavo prevzorčiti. To je bilo potrebno zato, da smo različne nize podatkov uskladili na skupno časovno enoto in bazo. Nato smo izračunali kapaciteto in določili SOC s pomočjo metode štetja naboja, ki je podrobneje opisano v poglavjih 3.3.2 in 4.3.1.


Kot smo v poglavju 2.5 opisali, kaj vse vpliva na baterijo, smo želeli preveriti trditve. Zanimalo nas je, ali je napetostna krivulja odvisna od toka. Ugotovili smo, da se, če praznimo baterijo z različnimi konstantnimi tokovi, napetostna krivulja spreminja, kar je razvidno na sliki 4.1. Najvišja je

krivulja pri 3 A, najnižja pa pri 13 A. Vzrok tega pojava je notranja upornost baterije.



Slika 4.1: Prikaz napetosti pri različnih tokovih.

Zanimalo nas je še dejstvo, če je napetost odvisna od temperature. Na polnjeno baterijo smo praznili s konstantnim tokom 6 A pri različnih temperaturah. Slika 4.2 kaže, da se napetostni krivulji med seboj razlikujeta, kar potrjuje trditev odvisnosti od temperature.



Slika 4.2: Prikaz napetosti ob enakem toku in spremenljivi temperaturi.

4.2 Poskusi

Oceno uspešnosti modelov smo preverili s spodaj navedenimi merami napake.

4.2.1 Srednja absolutna napaka

Srednja absolutna napaka (angl. mean absolute error (MAE)) je mera uspešnosti, ki je definirana kot povprečna absolutna razlika med napovedano in pravo vrednostjo [13]:

$$MAE = \frac{1}{N} \sum_{i=1}^N |f(i) - \hat{f}(i)| \quad (4.1)$$

- kjer je N število vseh primerov danega problema;
- $\hat{f}(i)$ napovedana vrednost i -tega primera;
- $f(i)$ prava vrednost i -tega primera.

4.2.2 Srednja kvadratna napaka

Srednja kvadratna napaka (angl. mean squared error (MSE)) je mera uspešnosti, ki je definirana kot povprečni kvadrat razlike med napovedano in pravo vrednostjo [13].

$$MSE = \frac{1}{N} \sum_{i=1}^N (f(i) - \hat{f}(i))^2 \quad (4.2)$$

- kjer je N število vseh primerov danega problema;
- $\hat{f}(i)$ napovedana vrednost i -tega primera;
- $f(i)$ prava vrednost i -tega primera.

4.2.3 Relativna srednja kvadratna napaka

Ker je velikost MSE odvisna od dejanskega razpona možnih vrednosti funkcije, je smiselno uporabiti relativno srednjo kvadratno napako (RMSE) [13]:

$$RMSE = \frac{N * MSE}{\sum_{i=1}^N (f(i) - \bar{f})^2} \quad (4.3)$$

- kjer je N število vseh primerov;
- MSE srednja kvadratna napaka;
- \bar{f} povprečna vrednost pravih vrednosti;
- $f(i)$ prava vrednost i -tega primera .

Relativna srednja kvadratna napaka je vedno pozitivna in manjša od 1 za uporabne modele. Pogosto se v praksi uporabljata tudi dve meri, in sicer koren srednje kvadratne napake in koren relativne srednje kvadratne napake.

4.2.4 Relativna srednja absolutna napaka

Ker je tudi velikost MAE odvisna od dejanskega razpona možnih vrednosti funkcije, je smiselno uporabiti relativno srednjo absolutno napako (RAE) [13]:

$$RMAE = \frac{N * MAE}{\sum_{i=1} |f(i) - \bar{f}|} \quad (4.4)$$

- kjer je N število vseh primerov danega problema;
- MAE srednja absolutna napaka;
- \bar{f} povprečna vrednost pravih vrednosti;
- $f(i)$ in prava vrednost i -tega primera.

Tudi relativna srednja absolutna napaka je pozitivna in manjša od 1 za sprejemljive modele.

4.2.5 Ocenjevanje učenja

Podatke smo razdelili na učno in testno množico v razmerju 80% proti 20%. En nabor polnjenja in praznjenja smo uporabili za končno testno množico, kar predstavlja razmerje med testno in učno množico. Za gradnjo modela smo uporabili prečno preverjanje ($k=5$) na učni množici, ki je bila uporabljena za nastavitve parametrov.

4.2.6 Mrežno iskanje

Mrežno iskanje smo izvajali v primerih, kjer je bilo potrebno poiskati parametre metode SVM, linearne regresije in napetostne meritve. Z njim vedno najdemo najboljši nabor parametrov, vendar s povečanjem atributov postane časovno drag. Iskanje smo razdelili na dve stopnji, in sicer:

- **prva stopnja** je obsegala iskanje parametrov skozi večji razpon, vendar z večjimi koraki;
- **druga stopnja** je obsegala iskanje parametrov skozi manjši razpon, vendar z manjšimi koraki. Uporabljena je bila le tam, kjer so bili rezultati pri predhodni stopnji dobri.

S takšnim pristopom smo se želeli izogniti favoriziranju določenega podprostora parametrov.

4.2.7 Programska oprema

Za razvoj skripte smo uporabili programski jezik Java v razvojnem okolju Eclipse. Tekom razvoja modela baterije smo uporabili Matlab. Njegove prednosti so preprosto pisanje programov in njihovo testiranje, omogoča preprosto izvajanje matričnih operacij, reševanje diferencialnih enačb ... Končna različica modela baterije je sprogramirana v programskem jeziku Java.

4.2.8 Filter z drsečim povprečjem

Za filtriranje rezultata smo uporabili filter z drsečim povprečjem. V rezultatih se je pojavljala napaka, ki se je kazala kot velika nemirnost izhodnih podatkov (hitri preskoki vrednosti SOC-a). Nekaj nemirnosti povzroči tudi menjava modelov, zato smo se odločili, da izhodni rezultat še dodatno filtriramo. S tem smo izločili prevelika nihanja v oceni SOC-a. Filter smo implementirali po enačbi 4.5 in nastavili parameter o velikosti okna na 200.

$$y_n = \frac{1}{\text{velikostOkna}}(x_n + x_{n-1} + \dots + x_{n-(\text{velikostOkna}-1)}) \quad (4.5)$$

4.3 Rezultati

Rezultate implementiranih metod smo ocenili na končni množici podatkov za katere so tudi prikazane vrednosti napake. Vsaka metoda je predstavljena s tremi slikami. Na prvi sliki je prikazan rezultat. Z rdečo barvo je prikazana referenčna vrednost štetja naboja, z zeleno je prikazan rezultat metode in z modro je prikazan rezultat filtra z drsečim povprečjem. Na drugi sliki je prikazana napaka pri uporabi filtra z drsečim povprečjem. Na tretji sliki je prikazan histogram, ki prikazuje distribucijo, povprečje in standardni odklon napake.

4.3.1 Metode integriranja

Pri metodah integriranja smo izbrali metodo štetja naboja, ki se uporablja v mnogo raziskavah, kot referenčna vrednost. Lahko se uporablja v kombinaciji z ostalimi metodami, kjer raziskovalci poskušajo omiliti njene slabosti.

Štetje naboja

Metoda štetja naboja je kratkoročno natančna in je enostavna za implementacijo. Ker nimamo podatka o resničnem SOC-u, smo jo uporabili kot referenčno vrednost v nadaljnjih raziskavah. Pred obdelavo smo podatke cikla ločili na dva dela. Posebej smo izračunali SOC za polnjenje in praznjenje. Za večjo natančnost smo se oprli na nekaj kalibracijskih točk. Ko se baterija začne prazniti, smo predpostavili, da je $SOC = 100\%$; ko je prazna, je $SOC = 0\%$ in obratno, ko se baterija začne polniti je $SOC = 0\%$, in ko je polna, je $SOC = 100\%$. Nekaj dodatnih težav je povzročalo dejstvo, da smo pri polnjenju s štetjem naboja vedno našli večje število amper ur kot je maksimalna kapaciteta baterije.

4.3.2 Neposredne meritve

Pri neposrednih meritvah smo izbrali metodi napetostne meritve in model baterije, saj sta najbolj smiselna za naše potrebe ter za izmerjene podatke.

Model baterije

Sprva smo po vzoru Baskar Vairmohana [8] želeli zgraditi model, ki se bo obnašal podobno kot naša baterija. Za nadomestno vezje smo uporabili spremenjeno Theveninovo vezje notranje upornosti. Avtor utemeljuje, da je izbral takšno vezje zaradi tega, ker je potreboval različna upora za popi-sovanje praznjenja in polnjenja. Zasnovani model je izrazil z diferencialnimi enačbami, ki jih je nato uporabil za izračun SOC-a. Glavni namen modela je na podlagi meritev določiti napetost odprtih sponk, ki jo je nato moč uporabiti za natančno določitev SOC-a. Avtor omenja, da je nastavljanje vrednosti posameznih vrednosti parametrov modela lahko težavno.

Sledili smo njegovemu postopku in poskusili model. Prilagodili smo ga našim potrebam, vendar smo po nekaj neuspešnih poskusih nastavljanja parametrov idejo opustili. Vrednosti parametrov modela smo iskali s pomočjo linearnega in mrežnega iskanja. Slednje je precej zahtevno, medtem ko ima linearno iskanje težave z lokalnimi minimumi. Spodletelemu poskusu je botrovalo tudi dejstvo, da je model prilagojen določenemu tipu baterij, kar ob spremembi tipa povzroča precejšnje nevšečnosti.

Napetostne meritve


Pri tej metodi smo poskusili oceniti SOC, glede na nivo napetosti. Nastala je ideja, da velik nelinearen problem razdelimo na manjše podprobleme.

Pri tej metodi razdelimo napetost na n enakih delov. Vsak del ostaja ločen z minimalno in maksimalno napetostjo. SOC izračunamo po formuli 4.6 [22]:

$$SOC = SOC_{min} + \frac{V_{tr} - V_{min}}{V_{max} - V_{min}}(SOC_{max} - SOC_{min}) \quad (4.6)$$

Ker vemo, da napetost sama po sebi ni dovolj za oceno SOC-a, smo najprej uporabili povprečno krivuljo pri polnjenju in praznjenju. Z ročnim razrezom delov krivulje na enake dele smo poskušali najti najboljše ujemanje z odsekoma linearno krivuljo. Po nekaj ročnih poskusih smo se odločili, da napišemo algoritem, ki bo najbolj optimalno razdelil našo krivuljo na linearne dele. Najboljše ujemanje smo zaznali v naslednjih primerih:


- 13 linearnih delov pri polnjenju, kar je razvidno na sliki 4.3. Napaka v ujemanju povprečne in naše krivulje se giblje med $-0,0327$ in $0,0051\%$, relativna srednja kvadratna napaka znaša $0,1847\%$.
- 20 linearnih delov pri praznjenju, kar je razvidno na sliki 4.4. Napaka v ujemanju povprečne in naše krivulje se giblje med $-0,392$ in $0,392\%$. Relativna srednja kvadratna napaka znaša $0,1125\%$.



Slika 4.3: Razrez napetosti povprečne krivulje pri polnjenju.

SOC	V
0,02	10,16
8,35	13,46
16,68	13,50
25,02	13,66
33,35	13,68
41,68	13,72
50,01	13,75
58,34	13,80
66,67	13,87
75,01	13,90
83,34	13,91
91,67	13,99
100	14,39

Tabela 4.1: Prikaz številskih vrednosti razreza.




Slika 4.4: Razrez napetosti povprečne krivulje pri praznjenju.

SOC	V
0	9,84
5,26	12,21
10,52	12,31
15,79	12,46
21,05	12,52
26,31	12,62
31,57	12,68
36,84	12,67
42,10	12,75
47,36	12,83
52,62	12,84
57,88	12,92
63,15	12,89
68,41	12,97
73,67	12,97
78,93	12,98
84,20	12,99
89,46	13,02
94,72	13,03
99,98	13,98

Tabela 4.2: Prikaz številskih vrednosti razreza.


Kot prikazuje slika 4.5a, rezultat metode kaže največje odstopanje v začetnem in sredinskem delu. V začetnem delu je velika napaka med napetostno krivuljo in njeno odsekoma linearno krivuljo. V sredinskem delu pa minimalna sprememba napetosti odraža veliko spremembo v SOC-u. Pri polnjenju se napaka pojavi v sredinskem in končnem delu, vendar manj intenzivno, kot pri praznjenju. Menimo, da v realnem sistemu metoda ne bi bila uporabna, saj nanjo vpliva tudi tok, ki se delno upošteva, medtem ko

temperatura in staranje baterije ne. Napaka, prikazana na sliki 4.5b, se giblje med - 11 in 12%, povprečna absolutna napaka pa znaša 4,3%. Na histogramu 4.5c je povprečna vrednost napake 0,8513%. Napaka je večja na pozitivni strani, kar potrjuje tudi dejstvo, da je približno 3500 primerov ocenjenih z 2,2% napake. Standardni odklon napake je 4,8776%.



(a) Prikaz ocene napolnjenosti baterije.

(b) Prikaz napake rezultata filtra z drsečim povprečjem.




(c) Prikaz histograma napake rezultata filtra z drsečim povprečjem.

Slika 4.5: Prikaz rezultatov pri napetostni meritvi.

Ker se povprečna krivulja med napetostmi ni najboljše obnašala, smo se odločili, da tokrat vzamemo več napetostnih krivulj. Imeli bomo 4 napetostne krivulje pri praznjenju z konstantnimi tokovi 3 A, 6 A, 10 A in 13 A in eno krivuljo pri polnjenju. Krivulje smo razrezali na 10 delov. Za toliko delov smo se odločili, ker je s to vrednostjo parametra napaka najmanjša, obenem pa modela ne prilagodimo preveč napetostni krivulji. Tok smo razdelili na

intervale, in sicer:

- med tokom od 2 A do 4 A uporabljamo krivuljo praznjenja 3 A;
- med tokom od 4 A do 5 A uporabljamo povprečje krivulj 3 A in 6 A;
- med tokom od 5 A do 7 A uporabljamo krivuljo 6 A;
- med tokom od 7 A do 9 A uporabljamo povprečje krivulj 6 A in 10 A;
- med tokom od 9 A do 11 A uporabljamo krivuljo 10 A;
- med tokom od 11 A do 12 A uporabljamo povprečje krivulj 10 A in 13 A;
- med tokom od 12 A do 14 A uporabljamo krivuljo praznjenja 13 A.




Slika 4.6: Prikaz razreza napetostne krivulje s konstantno obremenitvijo 3 A.

SOC	V
0	5,50
0,22	8,33
0,58	10,49
2,62	11,61
8,12	12,49
36,30	12,90
65,20	13,01
77,72	13,12
99,15	13,19
99,99	13,90

Tabela 4.3: Prikaz številskih vrednosti razreza.

Napetostna krivulja je pri 3 A med 5,5 V in 13,9 V. Na začetku in na koncu je sprememba SOC-a zelo majhna, vendar se napetost zelo intenzivno spreminja. Medtem ko je na sredini sprememba SOC-a 28,6%, je razlika v napetosti le 0,11 V. Iz slike 4.6 je razvidno, kako je krivulja razdeljena, številске vrednosti razdelitve pa so prikazane v tabeli 4.3.




Slika 4.7: Prikaz razreza napetostne krivulje s konstantno obremenitvijo 6 A.

SOC	V
0	10,72
2,11	11,64
6,77	12,31
32,47	12,72
48,32	12,79
53,25	12,83
71,00	13,01
98,29	13,08
99,60	13,20
99,99	13,98

Tabela 4.4: Prikaz številskih vrednosti razreza.

Napetostna krivulja je pri 6 A med 10,72 V in 13,98 V. Na sliki 4.7 je prikazan razrez napetostne krivulje. V tabeli 4.4 vidimo točne številске vrednosti razreza.




Slika 4.8: Prikaz razreza napetostne krivulje s konstantno obremenitvijo 10 A

SOC	V
0	10,53
1,44	11,14
4,63	11,83
8,66	12,24
17,99	12,49
38,02	12,71
67,51	12,85
81,97	12,93
99,11	13,0
99,98	13,98

Tabela 4.5: Prikaz številskih vrednosti razreza.

Napetostna krivulja je pri 10 A med 10,53 V in 13,98 V. Na sliki 4.8 je prikazan njen razrez in v tabeli 4.5 pripadajoče številke vrednosti razreza.




Slika 4.9: Prikaz razreza napetostne krivulje s konstantno obremenitvijo 13 A.

SOC	V
0,01	11,22
2,83	11,68
6,09	11,91
11,89	12,13
21,76	12,29
40,79	12,45
69,90	12,56
78,71	12,60
99,06	12,69
99,88	13,05

Tabela 4.6: Prikaz številskih vrednosti razreza.

Napetostna krivulja je pri 13 A med 11,22 V in 13,05 V. Na sliki 4.9 je prikazan njen razrez in v tabeli 4.6 so prikazane številke vrednosti razreza.




Slika 4.10: Prikaz razreza napetostne krivulje med polnjenjem.

SOC	V
0	11,53
1,46	12,47
5,6	13,25
16,66	13,53
25,17	13,65
55,36	13,77
64,96	13,86
71,23	12,99
88,9	13,94
100	14,20


Tabela 4.7: Prikaz številskih vrednosti razreza.

Napetostna krivulja je pri polnjenju med 11,53 V in 14,20 V. Slika 4.10 kaže razrez napetostne krivulje in v tabeli 4.7 so prikazane številske vrednosti razreza.



(a) Prikaz ocene napolnjenosti baterije.

(b) Prikaz napake rezultata filtra z drsečim povprečjem.



(c) Prikaz histograma napake rezultata filtra z drsečim povprečjem.

Slika 4.11: Prikaz rezultatov pri napetostnih meritvah.

Na sliki 4.11a je prikazan rezultat ocene SOC-a in njegove prave vrednosti. Na začetku je nefiltriran rezultat nenatančen zaradi nerobustnosti metode. Ko uporabimo filter z drsečim povprečjem, pridobimo večjo natančnost. Največja napaka se pojavi pri petnajsti uri. Menimo, da je večja sprememba toka povzročila to odstopanje. Absolutna povprečna napaka pri oceni SOC-a je 2,79%. Napaka se giblje med -10 in 14%, kar prikazuje slika 4.11b. Iz histograma 4.11c je razvidno, da je večje število primerov napake

na dveh mestih in sicer vrednosti napake - 2,5% in 0,5%. Potrebno je izpostaviti, da se približno v 500 primerih pojavi večja napaka, in sicer pri 11,8%. Povprečna vrednost napake je - 0,3667% standardni odklon napake pa znaša 4,2414%.

Metoda deluje zelo dobro pri danih temperaturnih pogojih, z večjo spremembo temperaturnih pogojev pa se rezultati poslabšajo. Preizkus smo opravili na podatkih s povprečno temperaturo 32°C. V danih temperaturnih pogojih se je absolutna povprečna napaka gibala okoli 10%, zato smo poskušali omiliti temperaturni problem. Težavo povzroča tudi ročna nastavitvev tabel in posledično so lahko nastavljene nenatančno v začetnem ter končnem delu.

4.3.3 Adaptivni sistemi


Pri adaptivnih sistemih smo uporabili metode strojnega učenja. Razširjen Kalmanov filter ne pride v poštev, saj se ponavadi uporablja v kombinaciji s štetjem naboja, ki je naša referenčna vrednost za oceno SOC-a, medtem ko je pri mehki logiki potrebno večje število meritev podatkov.

Linearna regresija


Linearna regresija lahko reši le linearen problem, kar nam v tem primeru ne koristi, saj je napovedovanje SOC-a izrazito nelinearno. Kot vhodni vektor podatkov smo uporabili tok in napetost. Podatki lahko včasih vsebujejo šum. Nanj smo hoteli vplivati z upoštevanjem prejšnjih stanj. Predpostavili smo dve dejstvi, da je časovni zamik med prispelima podatkomajhen in sprememba med podatkomajhen. Nato smo naleteli na težavo, na koliko stanj lahko vplivamo in kaj je najbolj optimalno za naš model. Potrebno je bilo najti ustrezno stopnjo polinoma, ki reši dani problem in vrednost, na koliko prejšnjih stanj je najbolj optimalno vplivati. Števili smo iskali s pristopom mrežnega iskanja in preizkusili vse možne stopnje polinomov med 1 in 4; prav tako smo upoštevali prejšnja stanja med 1 in 3.

Rezultati metode se gibljejo med 2,5 in 25% absolutne povprečne napake, odvisno od nastavitve parametrov. Polinom četrte stopnje se z linearno odvisnostjo zadnjih nekaj stanj in singularnost s tem povezanih matrik težko izračuna. Z višjimi stopnjami polinomskih stopenj se sicer rezultat izboljša, vendar problem postane kompleksnejši in s tem neuporaben za realni sistem. Odločili smo se, da uporabimo naslednje vrednosti, in sicer:


- **polnjenje:** polinom druge stopnje in upoštevanje treh prejšnjih stanj;
- **praznjenje:** polinom druge stopnje in upoštevanje dveh prejšnjih stanj.



(a) Prikaz ocene napolnjenosti baterije.



(b) Prikaz napake rezultata filtra z drsečim povprečjem.



(c) Prikaz histograma napake rezultata filtra z drsečim povprečjem.

Slika 4.12: Prikaz rezultatov pri linearni regresiji.

Rezultati so prikazani na sliki 4.12a. Največje odstopanje se nahaja pri praznjenju v območju med deseto in petindvajseto uro. Vzrok največje napake pri petindvajseti uri povzroči menjava modelov. Model linearne regresije se v povprečju zmoti za 3,31% in niha med vrednostima med - 11 in 8%, kar je razvidno na sliki 4.12b. Iz histograma 4.12c je razvidna distribucija napake. Največ primerov ima napako okoli 0,5%; izpostaviti velja, da je veliko napak okoli - 11%. Povprečna vrednost napake je - 0,9311% in standardni odklon napake znaša 4,5521%.


Metoda podpornih vektorjev

Za izvedbo učenja z metodo podpornih vektorjev smo morali za optimalne rezultate najprej ustrezno nastaviti naslednje parametre:


- **jedrna funkcija:** uporabili smo linearno, polinomsko in radialno bazno jedro (RBF). Linearno jedro smo po nekaj poskusih opustili, saj je v našem primeru neučinkovito in daje slabe rezultate. Polinomsko jedro so že uporabljali v preteklih raziskavah [10]. Odločili smo se za radialno bazno jedro, ki se tudi že pojavlja v prejšnjih raziskavah [5];
- **cena:** s tem parametrom določimo ceno napačne klasifikacije na učnih podatkih. Pri izbrani prenizki vrednosti je uspešnost klasifikacije nizka. Previsoka vrednost parametra pa se pretirano prilagodi učnim podatkom;
- **epsilon - ε :** s tem parametrom omogočamo nekaznovanje določenih napak do te vrednosti, s tem povečamo robustnost modela.

Pri metodi SVM smo za vhodne podatke najprej uporabili tok in napetost. Želeli smo najti čim bolj optimalen ε in C. Poiskali smo parameter ε med vrednostima 0,00025 in 0,9 in parameter C med 0 in 7. Z mrežnim iskanjem smo našli najbolj optimalno rešitev parametrov za oba modela, in sicer:


- pri polnjenju uporabimo vrednost ε -a 0,203 in vrednost C-ja 5.
- pri praznjenju uporabimo vrednost ε -a 0,4003 in vrednost C-ja 5.



(a) Prikaz ocene napolnjenosti baterije.



(b) Prikaz napake rezultata filtra z drsečim povprečjem.



(c) Prikaz histograma napake rezultata filtra z drsečim povprečjem.


Slika 4.13: Prikaz rezultatov pri SVM z jedrom RBF.

Kot je razvidno s slike 4.13a, se SVM dobro prilega. Glede na pravo vrednost ni večjih odstopanj. Ker uporabljamo le osnovna podatka tok in napetost, lahko nastopi težava pri večji spremembi temperature. Povprečna absolutna napaka je 3,3% in se giblje med - 9 in 10%, kot prikazuje slika 4.13b. SVM se največkrat zmoti za 0,5%, kar je razvidno iz histograma 4.13c. V mnogih primerih se napaka pojavlja med - 2 in - 8%. Povprečna vrednost napake je - 1,2238% in standardni odklon napake je 4,7671%.

Nato smo preizkusili metodo z novimi vhodnimi podatki in smo uporabili napetost, tok, spremembo toka in spremembo napetosti. Parametre smo iskali z mrežnim iskanjem. Z mrežnim iskanjem smo našli najbolj optimalno rešitev parametrov za oba modela, in sicer:


- pri polnjenju uporabimo vrednost ε -a 0,25 in vrednost C-ja 2;
- pri praznjenju uporabimo vrednost ε -a 0,56 in vrednost C-ja 6.5.

Uporabili smo RBF jedro iz že navedenih razlogov.



(a) Prikaz ocene napolnjenosti baterije.

(b) Prikaz napake rezultata filtra z drsečim povprečjem.



(c) Prikaz histograma napake rezultata filtra z drsečim povprečjem.

Slika 4.14: Prikaz rezultatov pri SVM z jedrom RBF.

Na sliki 4.14a so prikazani rezultati ocene SOC-a. V začetnem delu praznjenja je razvidno večje odstopanje, prav tako med deseto in petindvajseto uro ter med petintrideseto in štirideseto uro. Napaka se giblje med - 10 in 14%, kar je prikazano na sliki 4.14b. Kot vidimo na histogramu 4.14c, se v največ primerih pojavi napaka pri 0,5%. Povprečna vrednost napake je 0,0653% in standardni odklon napake je 5,9%.

Metodo SVM smo preizkusili tudi z vhodnimi podatki, kot so:

- $\Delta t \times I, \Delta t, I, \hat{SOC}, V, \Delta V;$
- $I, \hat{SOC}, V, \Delta V;$
- $I, V, \Delta V.$

Rezultati so bili slabši in zaradi tega niso bili vključeni. Poskusili smo tudi z vhodnimi podatki $\int_{t_{SOC0}}^{t_{SOCend}} I dt, V, I$, ki so rezultat izboljšali, vendar uporabljajo referenčno vrednost štetja naboja, zato rezultatov nismo predstavili.

4.3.4 Hibridne metode

Pri hibridnih metodah smo implementirali metodo podpornih vektorjev z napetostno meritvijo in linearno regresijo z napetostno meritvijo.

Metoda podpornih vektorjev z napetostno meritvijo

Slabost pri naši izvedbi napetostne meritve je velika temperaturna odvisnost. Zaradi tega smo poskušali narediti model, ki bo čimbolj robusten in se ne odziva na temperaturne spremembe. Atribut je bilo potrebno diskretizirati, ker nismo imeli dovolj meritev pri določeni temperaturi. Ker se baterija nahaja v realnem sistemu avtodoma, se temperatura preko dneva spreminja, dnevna sprememba znaša lahko tudi do 20° C. Določili smo naslednje vrednosti temperature:


- do 15°C;
- med 15°C in 25°C;
- več kot 25°C.

Poleg temperature in SOC-a napetostne meritve smo uporabili še attribute toka in napetosti.

Z mrežnim iskanjem smo našli najbolj optimalno rešitev parametrov za oba modela, in sicer:


- pri polnjenju uporabimo vrednost ε -a 0,2 in vrednost C-ja 5;
- pri praznjenju uporabimo vrednost ε -a 0,4 in vrednost C-ja 5.

Slika 4.15a prikazuje, da se v začetku praznjenja in pri petnajsti uri zaradi večje spremembe toka napaka poveča, vendar se dokaj hitro zmanjša. Na sliki 4.15b se napaka giblje med - 18 in 15%. Iz histograma 4.15c je razvidno, da je približno v 6000 primerih napaka okoli 0,5%. Povprečna vrednost napake je - 0,2826% in standardni odklon napake znaša 4,8770%. Ugotovili smo, da se ta model najbolj obnaša pri vseh testiranjih.



(a) Prikaz ocene napolnjenosti baterije.

(b) Prikaz napake rezultata filtra z drsečim povprečjem.



(c) Prikaz histograma napake rezultata filtra z drsečim povprečjem.


Slika 4.15: Prikaz rezultatov pri metodi podpornih vektorjev z napetostno meritvijo.

Linearna regresija z napetostno meritvijo

Uporabili smo enak podatkovni nabor kot pri metodi podpornih vektorjev z napetostno meritvijo. Z mrežnim iskanjem smo našli najbolj optimalno rešitev parametrov za oba modela, in sicer:


- **polnjenje:** polinom tretje stopnje in upoštevanje enega prejšnjega stanja;
- **praznjenje:** polinom druge stopnje in upoštevanje enega prejšnjega stanja.

Na sliki 4.16a so prikazani rezultati metode. Velika napaka v začetku je povezana z preveliko občutljivostjo na spremembe vhodnih podatkov. Napaka se giblje med - 12 in 70%, kar vidimo na sliki 4.16b. Histogram 4.16c kaže, da ima nekaj čez 9000 primerov napako 0,5%. Srednja vrednost napake je 0,6637%, standardni odklon napake pa znaša 5,8264%.



(a) Prikaz ocene napolnjenosti baterije.

(b) Prikaz napake rezultata filtra z drsečim povprečjem.



(c) Prikaz histograma napake rezultata filtra z drsečim povprečjem.

Slika 4.16: Prikaz rezultatov pri linearni regresiji z napetostno meritvijo.

4.4 Primerjava implementiranih metod

V tabelah se pojavijo naslednje okrajšave:

Ime	Okrajšava
Linearna regresija	LR
SVM z RBF	SVM
Napetostna meritev	PLF

Za gradnjo modelov smo uporabili prečno preverjanje. Uspešnost zgrajenih modelov so prikazani v tabeli 4.8. Na koncu smo zgrajene modele za ocenjevanje SOC-a preverili na neodvisni testni množici. Rezultati so prikazani v tabeli 4.9 in 4.10. V tabeli 4.9, 4.10 so prikazane metoda linearne regresije, metoda podpornih vektorjev, napetostne meritve, metoda podpornih vektorjev z napetostno meritvijo in linearna regresija z napetostno meritvijo. Pri stolpcih *Da* smo rezultat filtrirali z uporabo filtra z drsečim povprečjem. Napake so izračunane na podlagi filtriranega rezultata in njene prave vrednosti. Pri stolpcih *Ne* je napaka, ki je izračunana na podlagi rezultata in njene prave vrednosti. V tabeli 4.8 stolpci *C* predstavljajo napako pri modelu polnjenja in stolpci *D* napako v modelu praznjenja.

Za izbiro modela smo upoštevali več kriterijev in sicer povprečno absolutno in povprečno kvadratno napako, največjo pozitivno/negativno napako ter distribucijo napake. Odločili smo se, da prikažemo rezultate najboljše metode po našem mnenju iz vsake skupine, kar kaže slika 4.17.

Z rdečo barvo je prikazana naša referenčna vrednost štetja naboja. Prikazane metode odstopajo v podobnih časovnih intervalih, vendar nekatere bolj intenzivno, kot druge. Z nekaj izboljšavami pri napetostnih metodah (upoštevanje toka), smo dosegli večjo točnost pri oceni stanja napolnjenosti, kot je to sposobna oceniti metoda podpornih vektorjev. Slednja se v danem primeru tudi najslabše obnaša. Značilnost metod je, da se največ zmotijo v začetku praznjenja in okoli petnajste ure pri praznjenju in proti koncu polnjenja, natančneje med petintrideseto in štirideseto uro. V celoti

gledano najboljše oceni stanje napolnjenosti metoda podpornih vektorjev z napetostno meritvijo, ki je vgrajena v avtodomu.

	SVM Z RBF		SVM Z RBF in PLF		LR Z PLF	
	C	D	C	D	C	D
MAE	6,0815	5,2022	1,309	2,9925	1,4015	3,3522
MSE	83,1822	24,2167	4,1827	21,8852	3,9228	23,7667
RSE	0,0810	0,0725	0,0041	0,0264	0,0038	0,0286
RAE	0,2163	0,2167	0,0467	0,1590	0,05	0,1352


Tabela 4.8: Prikaz rezultatov pri prečnem preverjanju.

	SVM Z RBF in PLF		LR Z PLF	
Filter	Ne	Da	Ne	Da
MAE	2,3911	2,735	1,6726	2,7706
MSE	18,45	16,4264	7,4937	34,382
RSE	0,025	0,026	0,0072	0,0328
RAE	0,0921	0,1590	0,0588	0,0975

Tabela 4.9: Prikaz rezultatov metod z končno testno množico.

	LR		SVM Z RBF		PLF	
Filter	Ne	Da	Ne	Da	Ne	Da
MAE	3,3002	3,5935	3,1717	4,0588	2,7941	3,2901
MSE	21,2062	22,5144	19,3739	24,2167	16,8917	18,12
RSE	0,0212	0,0288	0,0195	0,0245	0,027	0,032
RAE	0,1196	0,1303	0,1150	0,1471	0,099	0,1165

Tabela 4.10: Prikaz rezultatov metod z končno testno množico.



Slika 4.17: Prikaz najboljših rezultatov.

Poglavje 5

Zaključek

Napolnjenosti baterije ne moremo meriti direktno, zato je za ocenjevanje njene napolnjenosti potrebno razviti primerne posredne metode. Te lahko razdelimo na več skupin:

- metode, ki temeljijo na fizikalnih modelih in uporabljajo neposredne meritve (metode neposrednih meritev),
- metode, ki merijo tok praznjenja in polnjenja (metode integriranja),
- metode, ki se učijo iz preteklih ocen in se prilagajajo (adaptivne metode),
- kombinacija gornjih metod (hibridne metode).

Iz vsake skupine je bila izbrana vsaj ena metoda, ki smo jo razvili in preizkusili. Iz skupine neposrednih meritev je bila razvita in preizkušena metoda napetostne meritve, iz skupine metod integriranja smo izbrali štetje naboja, pri skupini adaptivnih sistemov smo implementirali metodo podpornih vektorjev, linearno regresijo ter iz skupine hibridnih metod, metodo podpornih vektorjev z napetostno meritvijo in linearno regresijo z napetostno meritvijo.

Pri napetostni meritvi so rezultati slabi, če upoštevamo samo napetost. Če upoštevamo še tok, postane metoda za oceno SOC-a natančnejša. Vendar ostaneta še dve pomankljivosti, saj ne upoštevamo odstopanje temperature

in staranja baterije. Štetje naboja smo uporabili kot referenčno vrednost, zato ga nismo kombinirali z ostalimi metodami, kar ostali raziskovalci velikokrat poskušajo. Pri adaptivnih sistemih smo uporabili linearno regresijo in metodo podpornih vektorjev. Pri linearni regresiji smo uporabili parametra tok in napetost. Hiperparametra metode sta upoštevanje prejšnjih stanj in stopnja polinoma, ki ga uporabljamo pri aproksimaciji. Tudi pri metodi podpornih vektorjev se je izkazal za najboljšega enak nabor podatkov. Pri hibridnih metodah smo uporabili kombinacijo neposrednih metod in adaptivnih sistemov. Najprej smo izračunali SOC pri napetostni meritvi. Ta rezultat skupaj s trenutno napetostjo, tokom in temperaturo uporabimo kot vhodni podatek za oceno z adaptivno metodo.

Za najboljšo metodo se je izkazala zadnja kombinacija, zato smo jo dejansko vdelali v avtodom. Rezultat diplomskega dela tako ni le teoretičen, temveč bo uporaben tudi v industrijski praksi.

Literatura

- [1] Battery terms glossary. Dosegljivo: <http://www.solar-electric.com/battery-terms-glossary.html>. [Dostopno 15. 7. 2015].
- [2] Inaccuracies of estimating remaining cell capacity with voltage measurements alone. Dosegljivo: <http://www.maximintegrated.com/en/app-notes/index.mvp/id/121>.
- [3] Regresijska analiza. Dosegljivo: http://lab.fs.uni-lj.si/kes/eksperimentalno_modeliranje_v_eps.
- [4] Support vector machine. Dosegljivo: https://en.wikipedia.org/wiki/Support_vector_machine. [Dostopno 17. 6. 2015].
- [5] J.C. Alvarez Anton, P.J. Garcia Nieto, C. Blanco Viejo, and J.A. Vilan Vilan. Support vector machines used to estimate the battery state of charge. *Power Electronics, IEEE Transactions on*, 28(12):5919–5926, Dec 2013.
- [6] Janko Petrovčič Andrej Debenjak, Gregor Papa. Modularni sistem za upravljanje li-ion baterije.
- [7] Wen-Yeau Chang. The state of charge estimating methods for battery: a review. *ISRN Applied Mathematics*, 2013, 2013.
- [8] John N. Chiasson and Baskar Vairamohan. Estimating the state of charge of a battery. *IEEE Trans. Contr. Sys. Techn.*, 13(3):465–470, 2005.

-
- [9] Corinna Cortes and Vladimir Vapnik. Support-vector networks. *Mach. Learn.*, 20(3):273–297, September 1995.
 - [10] Terry Hansen and Chia-Jiu Wang. Support vector based battery state of charge estimator. *Journal of Power Sources*, 141(2):351–358, 2005.
 - [11] Simon Haykin. *Neural Networks: A Comprehensive Foundation*. Prentice Hall PTR, Upper Saddle River, NJ, USA, 2nd edition, 1998.
 - [12] J. Jiang and C. Zhang. *Fundamentals and Application of Lithium-ion Batteries in Electric Drive Vehicles*. Wiley, 2015.
 - [13] I. Kononenko and M.R. Šikonja. *Inteligentni sistemi*. Založba FE in FRI, 2010.
 - [14] Igor Kononenko and Matjaz Kukar. *Machine Learning and Data Mining: Introduction to Principles and Algorithms*. Horwood Publishing Limited, 2007.
 - [15] Zihelr Kopač. Baterije, izbrana poglavja iz uporabne fizike.
 - [16] Daniel Le and Xidong Tang. Lithium-ion battery state of health estimation using ah-v characterization. In *Proceedings of the Annual Conference of Prognostics and Health Management (PHM) Society, Montreal, QC, Canada*, volume 2529, page 367373, 2011.
 - [17] Seongjun Lee, Jonghoon Kim, Jaemoon Lee, and BH Cho. State-of-charge and capacity estimation of lithium-ion battery using a new open-circuit voltage versus state-of-charge. *Journal of power sources*, 185(2):1367–1373, 2008.
 - [18] D. Linden and T. Reddy. *Handbook of Batteries*. McGraw-Hill handbooks. McGraw-Hill Education, 2001.
 - [19] Vid Merljak. Kako pravilno polniti akumulatorje. Dosegljivo: http://mafija.fmf.uni-lj.si/seminar/files/2012_2013/

- Kako_pravilno_polniti_akumulatorje_(Vid_Merljak).pdf. [Dostopno 10. 6. 2015].
- [20] Matej Perše. Sledenje športnikov na osnovi kalmanovega filtra.
- [21] Sabine Piller, Marion Perrin, and Andreas Jossen. Methods for state-of-charge determination and their applications. *Journal of power sources*, 96(1):113–120, 2001.
- [22] Valer Pop, Henk Jan Bergveld, Dmitry Danilov, Paul P.L. Regtien, and Peter H.L. Notten. *Battery Management Systems: Accurate State-of-Charge Indication for Battery-Powered Applications (Philips Research Book Series) (Philips Research Book Series)*. Springer Publishing Company, Incorporated, 1 edition, 2008.
- [23] Alvin J Salkind, Craig Fennie, Pritpal Singh, Terrill Atwater, and David E Reisner. Determination of state-of-charge and state-of-health of batteries by fuzzy logic methodology. *Journal of Power Sources*, 80(1):293–300, 1999.
- [24] Vučko Simon. Metode določanja stanja napolnjenosti baterij.
- [25] MIT Electric Vehicle Team. A guide to understanding battery specifications. Dosegljivo: http://web.mit.edu/evt/summary_battery_specifications.pdf. [Dostopno 24. 7. 2015].
- [26] N. Watrin, B. Blunier, and A. Miraoui. Review of adaptive systems for lithium batteries state-of-charge and state-of-health estimation. In *Transportation Electrification Conference and Expo (ITEC), 2012 IEEE*, pages 1–6, June 2012.
- [27] S. Weisberg. *Applied Linear Regression*. Wiley Series in Probability and Statistics. Wiley, 2013.

- [28] Ian H. Witten, Eibe Frank, and Mark A. Hall. *Data Mining: Practical Machine Learning Tools and Techniques*. Morgan Kaufmann Publishers Inc., San Francisco, CA, USA, 3rd edition, 2011.